Teil II. Elementare Analysewerkzeuge

Prof. Dr. rer. nat. Uwe Aßmann

Institut für Software- und Multimediatechnik

Lehrstuhl Softwaretechnologie

Fakultät für Informatik

TU Dresden

http://st.inf.tu-dresden.de

Version 13-1.0, 05.12.13

20. Parser-Generatoren im Technikraum Grammarware

1) Grundlagen
2) Beispiel Taschenrechner

Literatur

- Obligatorisch:
- http://www.antlr.org
- Zusätzlich:
  - Cocktail www.cocolab.de, die Compiler-Toolbox für die schnellsten Compiler der Welt (kommerziell, Demoversionen erhältlich)

Phasen eines Werkzeugs und ihre erzeugenden Werkzeuge

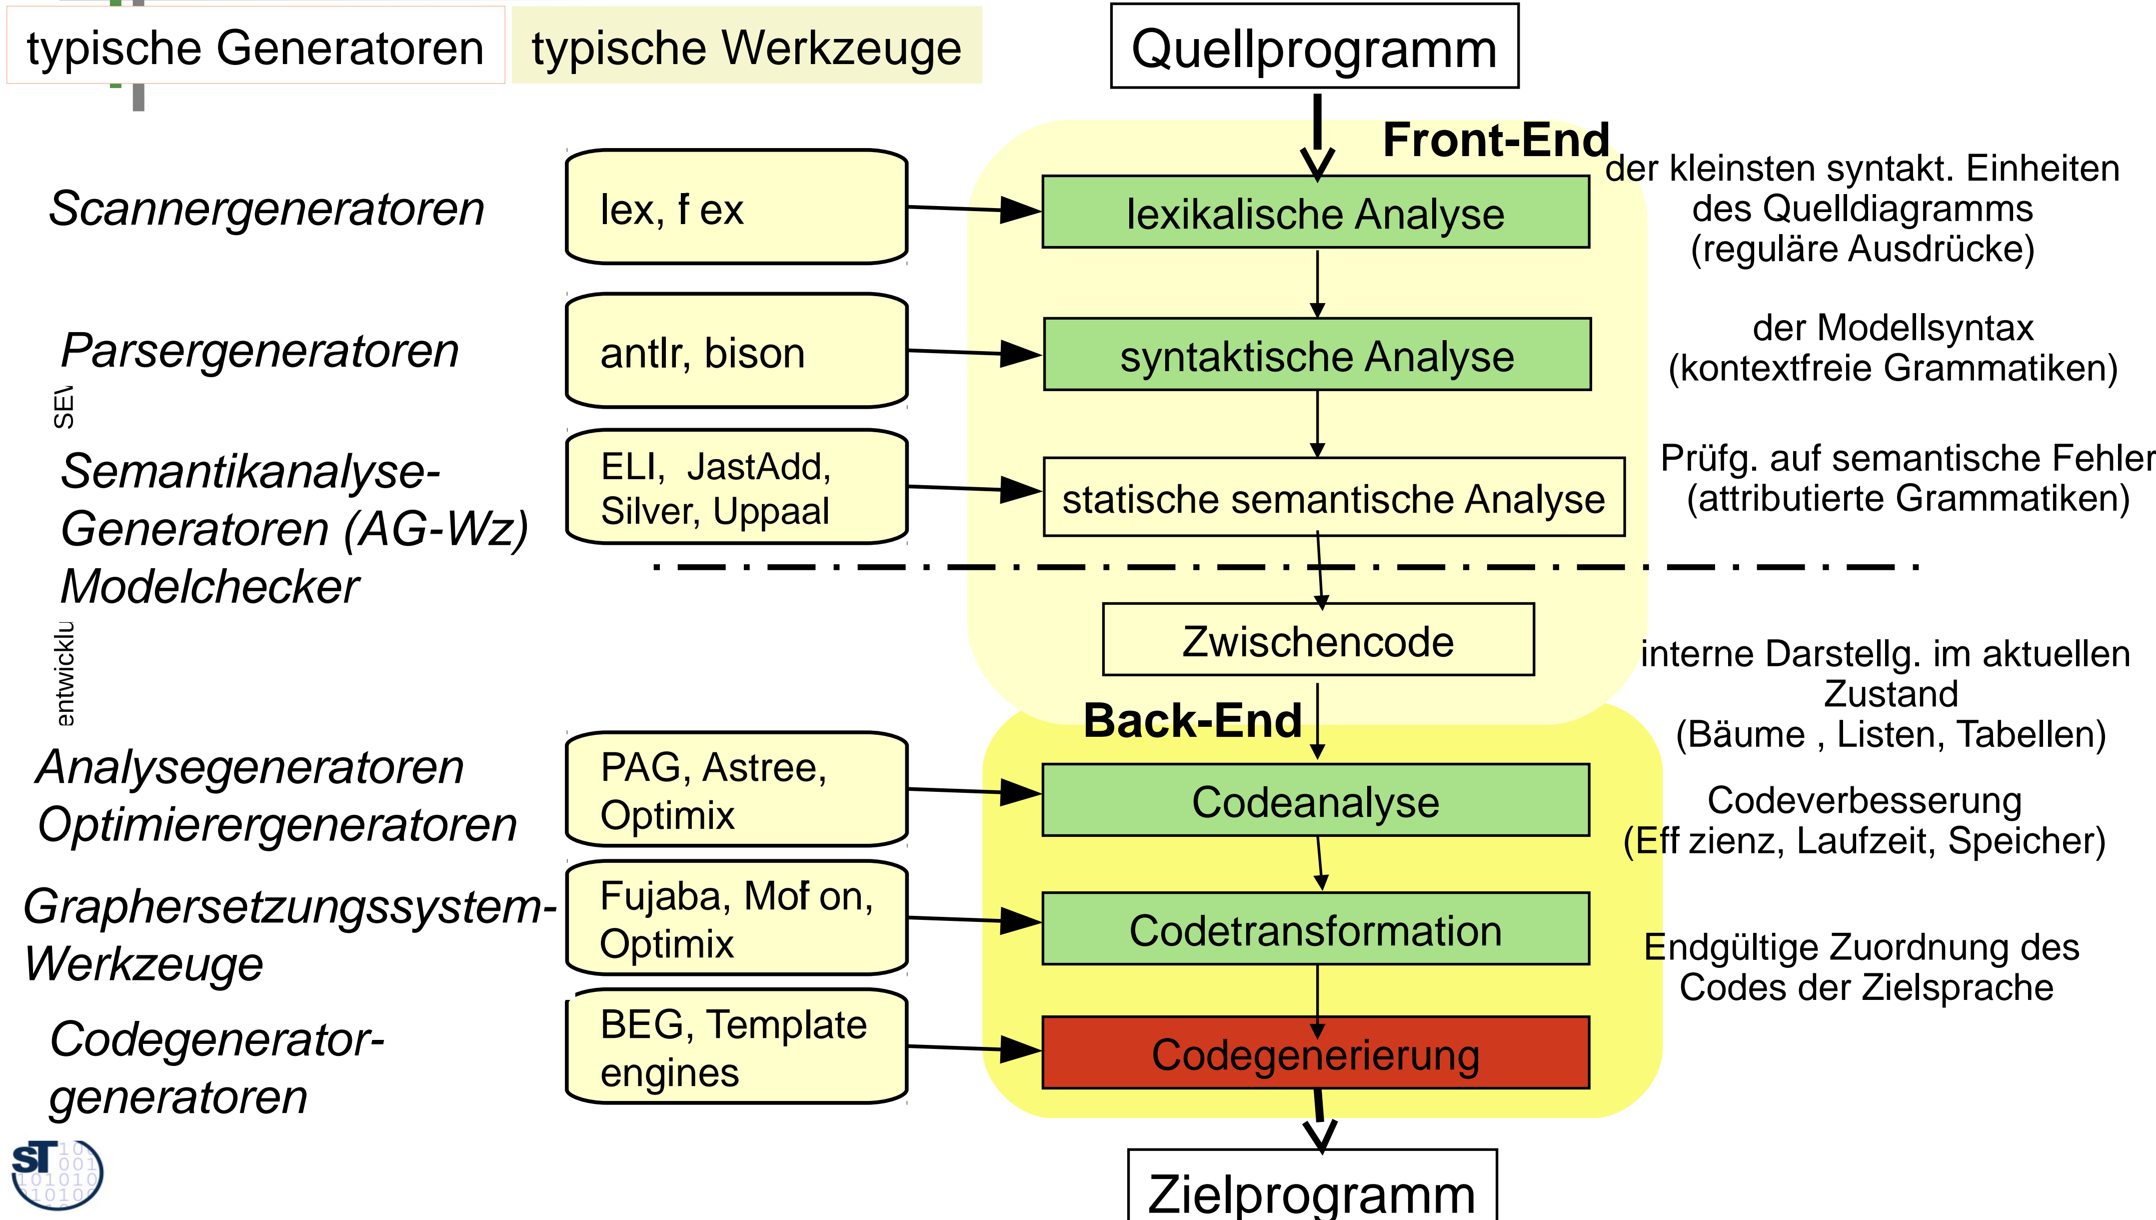

Phasen eines Importers in ein Repository und die erzeugenden Werkzeuge

typische Generatoren	typische Werkzeuge	Quellprogramm	
		Front-End	
Scannergeneratoren	lex, f ex	lexikalische Analyse	der kleinsten syntakt. Einheiten des Quelldiagramms (reguläre Ausdrücke)
Parsergeneratoren	antlr bison	syntaktische Analyse	der Modellsyntax (kontextfreie Grammatiken)
Constraint checkers	DCL wie OCL, AG, Logik	statische semantische Analyse	Prüfg. auf semantische Fehler (attributierte Grammatiken)
		Interne Repräsentation (Zwischencode, interne Modelle)	
Query and metric engines	DQL, CQL	Qualitätsanalyse	Messung der Qualität des Modells/Codes
Refactoring engine	RSL	Refactoring	Semantik-erhaltende Restrukturierung
Transformation engine	DTL	Transformation	Term- oder Graph-Transformation

Wdh: Nutzung von generierten Parsern zum Import in Repositorien

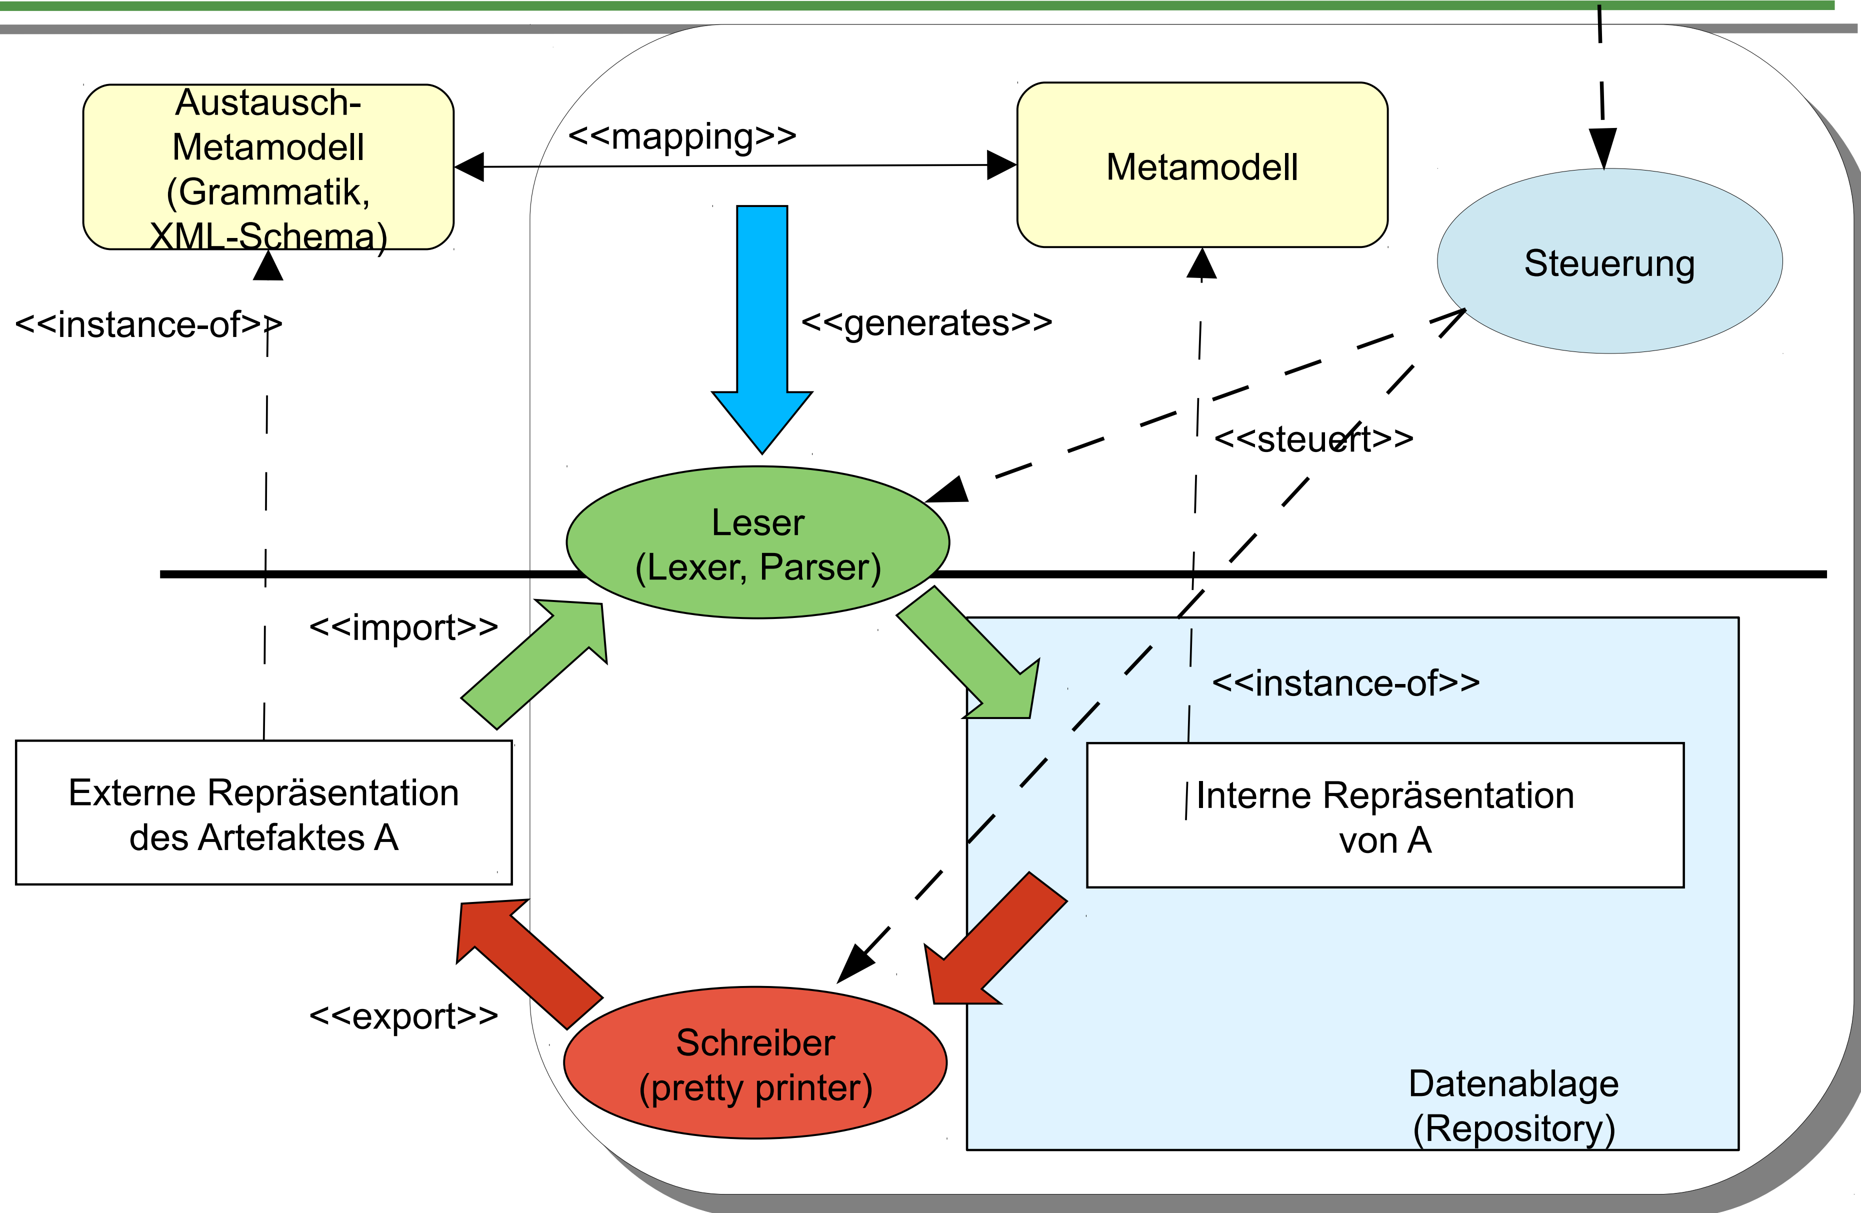

Problem

- Parsen eines Programms, Modells oder Artefakts bedeutet, seine kontextfreie Syntax zu erkennen
- Parser sind die ersten Phasen eines Werkzeugs, denn es muss ein Artefakt importieren und damit ihn parsen
- Parsen erzeugt einen *Syntaxbaum*
- Parser wurden ursprünglich von Hand geschrieben (Compilerbau), heute generiert man sie aus *Grammatiken in EBNF*
  - **Parser** erkennt die Struktur des Textes anhand der Grammatik (“Zerteiler”)
  - **Baumaufbauer (Baumkonstruktor)** erzeugt einen abstrakten Syntaxbaum. Normalerweise wird er mit dem Parser verschränkt.

Wie arbeite ich flexibel mit mehreren Programmiersprachen oder DSL?

Antwort

- Bidirektionale Abbildung zwischen Technikraum “Grammarware” und einem anderen Technikraum, wie z.B. “Treeware” oder “Modelware”

In dem ich aus Grammatiken Parser (Zerteiler und Baumkonstruktoren) generiere

und

zusätzlich Prettyprinter (Codegenerator)

Beispiel EMFText

- Nutzt Parser-Generator ANTLR zur Generierung von Parsern
  - Parser und Metamodell werden aufeinander abgebildet (mapping), um konkrete auf abstrakte Syntax abzubilden
- Nutzt schablonengesteuerte Codegenerierung zur Erzeugung von Text und Programmen (siehe später).

Beispiel: ANTLR www.antlr.org

- In den 90ger Jahren gab es für C viele Parsergeneratoren
  - Cocktail's lalr, ell, lark www.cocolab.de
  - fnc2
  - flex und bison (gnu)
- Für Java ist ANTLR populär geworden
  - LL(k)
  - Generierter Parser mit Algorithmus “rekursiver Abstieg”
  - Etwas “gefärbte” Seite mit Geschichte
    http://www.bearcave.com/software/antlr/antlr_expr.html

/Users/bovet/ Demo/objc.g

- parameter_declaration
- identifier_list
- initializer
- initializer_list
- type_name
- abstract_declarator
- direct_abstract_declarator
- typedef_name
- Statement
  - statement
  - labeled_statement
  - expression_statement
  - compound_statement
  - statement_list
  - selection_statement
  - iteration_statement
  - jump_statement
- Expression
- Lexer

```
compound_statement
    :   RCURLY declaration_list? statement_list? LCURLY
    ;

statement_list
    :   statement+
    ;

selection_statement
    :   'if' LPAREN expression RPAREN statement ('else' statement)?
    |   'switch' LPAREN expression RPAREN statement
    ;

iteration_statement
    :   'while' LPARE
    |   'do' statement
    |   'for' LPAREN e                              n? RPAREN statement
    ;

jump_statement
    :   'goto' identi
    |   'continue' SE
    |   'break' SEMI
    |   'return' expre
    ;
```

Enter rule name:

st

- struct_or_union_specifier
- storage_class_specifier
- struct_or_union
- struct_declaration_list
- struct_declaration
- struct_declarator_list
- struct_declarator
- statement
- statement_list
- string

Zoom | Show NFA

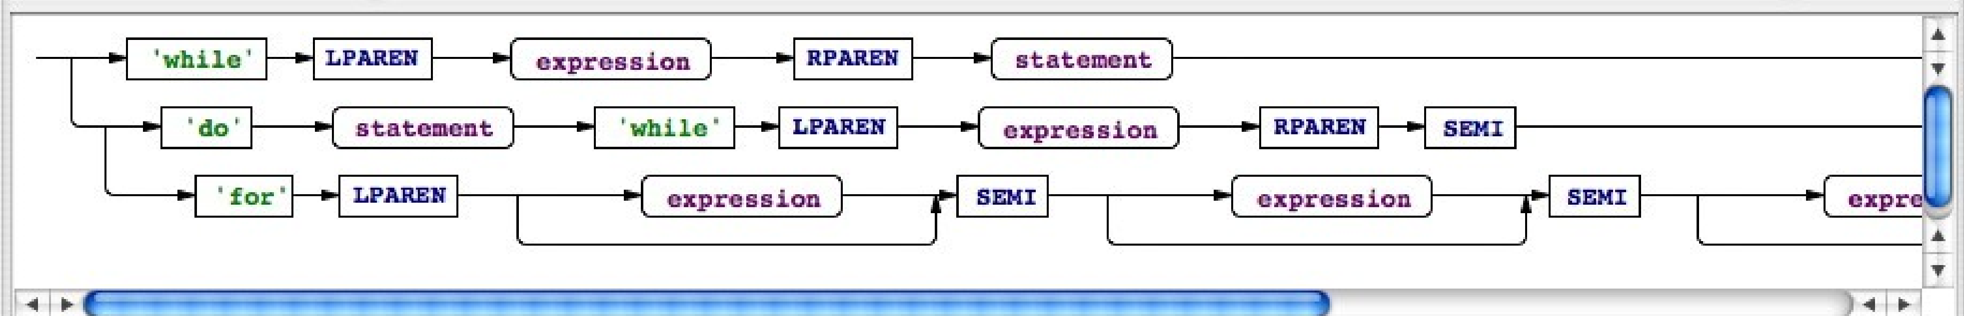

Syntax Diagram | Interpreter | Debugger | Console

129 rules | 452:23

/Users/bovet/ Grammars/java.g

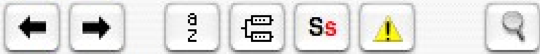

- handler
- expression
- expressionList
- assignmentExpression
- conditionalExpression

```
// the mother of all expressions
expression
    :   assignmentExpression

    ;
```

field

```
public void main() {
    int a = 2+3;
}
```


Zoom

132 rules | 528:1

/Users/bovet/Development/Research/depot/antlr/examples-v3/java/java.g

- interfaceBodyDeclaration
- interfaceMemberDecl
- interfaceMethodOrFieldDecl
- interfaceMethodOrFieldRest
- methodDeclaratorRest
- voidMethodDeclaratorRest
- interfaceMethodDeclaratorRest
- interfaceGenericMethodDecl
- voidInterfaceMethodDeclaratorRest
- constructorDeclaratorRest
- constantDeclarator
- variableDeclarators
- variableDeclarator
- variableDeclaratorRest
- constantDeclaratorsRest
- constantDeclaratorRest
- variableDeclaratorId
- variableInitializer
- arrayInitializer
- modifier

```
variableDeclaratorId
        :       Identifier ('[' ']')*
        ;

variableInitializer
        :       arrayInitializer
        |       expression
        ;

arrayInitializer
        :       '{' (variableInitializer (',' variableInitializer)* (',
        ;

modifier
    :   annotation
    |   'public'
        'protected'
        'private'
        'static'
        'abstract'
        'final'
        'native'
        'synchronized'
        'transient'
        'volatile'
        'strictfp'
        ;
```

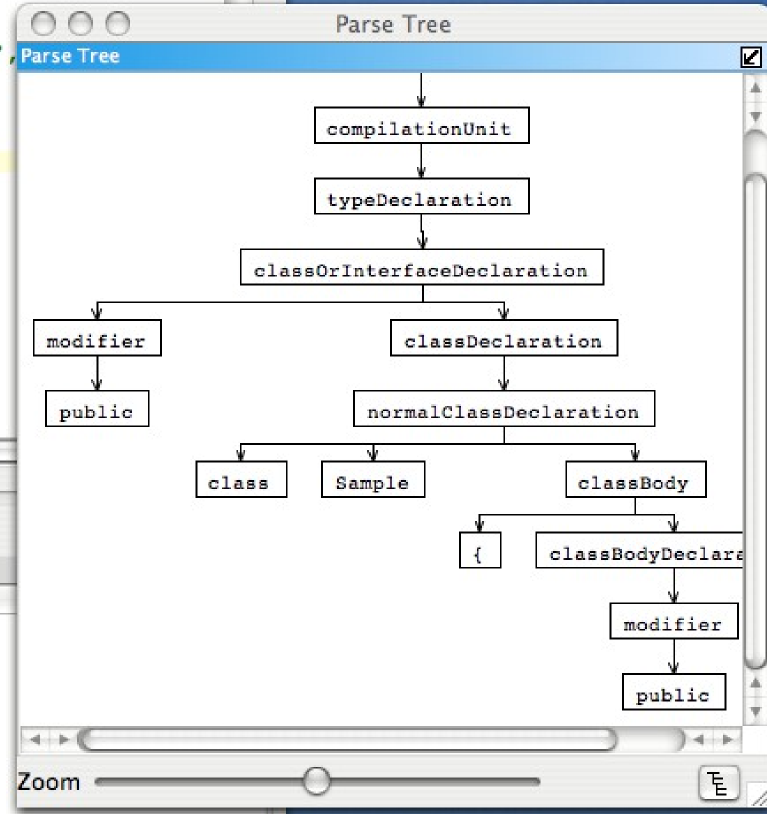

Break on: All Location Consume LT Exception

Input

```
public class Sample {
  public void main() {
    System.out.println("Hello, world");
  }
}
```

Stack

#	Rule
0	compilationUnit
1	typeDeclaration
2	classOrInterfaceDeclaration
3	classDeclaration
4	normalClassDeclaration
5	classBody
6	classBodyDeclaration
7	modifier

Input | Output | Parse Tree | AST | Stack | Events

Syntax Diagram | Interpreter | Debugger | Console

148 rules (2 warnings) | 254:9 | Warnings reported in console

/Users/bovet/ Grammars/java.g

Zoom

Show NFA

(1/2) Decision can match input such as "default" using multiple alternatives

Alternatives: 1 2

casesGroup
aCase
caseSList
statement

aCase caseSList
'case' expression COLON
'default'
statement

compoundStatement
declaration SEMI
expression SEMI
modifiers classDefinition
IDENT COLON statement
'if' LPAREN expression RPAREN statement 'else' statement
'for' LPAREN forInit SEMI forCond SEMI forIter RPAREN statement
'while' LPAREN expression RPAREN statement
'do' statement 'while' LPAREN expression RPAREN SEMI
'break' IDENT SEMI
'continue' IDENT SEMI
'return' expression SEMI
'switch' LPAREN expression RPAREN LCURLY casesGroup RCURLY
tryBlock

Syntax Diagram | Interpreter | Debugger | Console

132 rules (6 warnings) 433:1

/Users/bovet/mantra.g

- compilationUnit
- packageDefinition
- importDefinition
- typeDefinition
- classDefinition
- interfaceDefinition
- methodDefinition
- formalArgs

```
classDefinition[MantraAST mod]
scope {
  String name;
}
    :   'class' ID ('extends' sup=classname)? ('implements' i+=classname (',' i+=classname)*)?
        {$classDefinition::name = $ID.text;}
        '{'
        (   variableDefinition
        |   methodDefinition
        )*
```

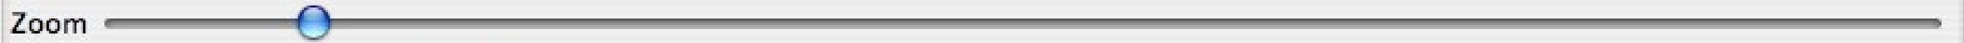

Zoom

'object' 'int' 'boolean' ID 'int' 'public'..'abstract' ID 'void' 'float' 'long' '.' ';' ID '(' {',', '='}

s0 s2 s3 s5 s6 s7 s8 s22 s23 s32 s33=>2 s34=>1

Syntax Diagram | Interpreter | Debugger | Console | Decision 10 of "classDefinition"

59 rules (1 warnings) | 56:5

13.2 Ein Taschenrechner

```
grammar Expr;
@header {
package test;
import java.util.HashMap;
}
@lexer::header {package test;}
@members {
/** Map variable name to Integer object holding value */
HashMap memory = new HashMap();
}
prog:   stat+ ;

stat:   expr NEWLINE {System.out.println($expr.value);}
    |   ID '=' expr NEWLINE
        {memory.put($ID.text, new Integer($expr.value));}
    |   NEWLINE
    ;
expr returns [int value]
    :   e=multExpr {$value = $e.value;}
        (   '+' e=multExpr {$value += $e.value;}
        |   '-' e=multExpr {$value -= $e.value;}
        )*
    ;
multExpr returns [int value]
    :   e=atom {$value = $e.value;} ('*' e=atom {$value *= $e.value;})*
    ;
atom returns [int value]
    :   INT {$value = Integer.parseInt($INT.text);}
    |   ID
        {
        Integer v = (Integer)memory.get($ID.text);
        if ( v!=null ) $value = v.intValue();
        else System.err.println("undefined variable "+$ID.text);
        }
    |   '(' e=expr ')' {$value = $e.value;}
    ;
ID  :   ('a'..'z'|'A'..'Z')+ ;
INT :   '0'..'9'+ ;
NEWLINE:'\r'? '\n' ;
WS  :   (' '|'\t')+ {skip();} ;
```

Ansteuerung

```
import org.antlr.runtime.*;
public class Test {
    public static void main(String[] args) throws Exception
{
        ANTLRInputStream input = new
ANTLRInputStream(System.in);
        ExprLexer lexer = new ExprLexer(input);
        CommonTokenStream tokens = new
CommonTokenStream(lexer);
        ExprParser parser = new ExprParser(tokens);
        parser.prog();
    }
}
```

/Users/bovet/ Grammars/Demo/Expr.g

- prog
- stat
- expr
- multExpr
- atom
- ID
- INT
- NEWLINE
- WS

```
grammar Expr;

@header {
package test;
import java.util.HashMap;
}

@lexer::header {package test;}

@members {
/** Map variable name to Integer object holding value */
HashMap memory = new HashMap();
}

prog:   stat+ ;

stat:   expr NEWLINE {System.out.println($expr.value);}
    |   ID '=' expr NEWLINE
        {memory.put($ID.text, new Integer($expr.value));}
    |   NEWLINE
    ;

expr returns [int value]
    :   e=multExpr {$value = $e.value;}
        (   '+' e=multExpr {$value += $e.value;}
        |   '-' e=multExpr {$value -= $e.value;}
        )*
```

prog | Line Endings: Unix (LF) | Ignore rules: WS | Guess

2+3*4

<grammar Expr> → prog → stat → expr, [ ]; expr → multExpr, +, multExpr; multExpr → atom → 2; multExpr → atom → 3, *, atom → 4

Zoom

Syntax Diagram | Interpreter | Debugger | Console

9 rules | 1:1 | Writable

/Users/bovet/ Grammars/Demo/Expr.g

- prog
- stat
- expr
- multExpr
- atom
- ID
- INT
- NEWLINE
- WS

```
expr returns [int value]
    :   e=multExpr {$value = $e.value;}
        (   '+' e=multExpr {$value += $e.value;}
        |   '-' e=multExpr {$value -= $e.value;}
        )*
    ;

multExpr returns [int value]
    :   e=atom {$value = $e.value;} ('*' e=atom {$value *= $e.value;})*
    ;

atom returns [int value]
    :   INT {$value = Integer.parseInt($INT.text);}
    |   ID
        {
        Integer v = (Integer)memory.get($ID.text);
        if ( v!=null ) $value = v.intValue();
        else System.err.println("undefined variable "+$ID.text);
        }
    |   '(' e=expr ')' {$value = $e.value;}
    ;

ID  :   ('a'..'z'|'A'..'Z')+ ;
INT :   '0'..'9'+ ;
NEWLINE:'\r'? '\n' ;
```

Break on: All | Location | Consume | LT | Exception — Break on Location

Input

2

Parse Tree

root → prog → stat → expr → multExpr → atom → 2

Zoom

Stack

#	Rule
0	prog
1	stat
2	expr
3	multExpr
4	atom

Input | Output | Parse Tree | AST | Stack | Events

Syntax Diagram | Interpreter | Debugger | Console

9 rules | 35:13 | Writable

/Users/bovet/ Grammars/Demo/Expr.g

prog
stat
expr
multExpr
atom
ID
INT
NEWLINE
WS

```
grammar Expr;

@header {
package test;
import java.util.HashMap;
}

@lexer::header {package test;}

@members {
/** Map variable name to Integer object holding value */
HashMap memory = new HashMap();
}

prog:   stat+

stat:   expr NEWLINE {System.out.println($expr.value);}
    |   ID '=' expr NEWLINE
        {memory.put($ID.text, new Integer($expr.value));}
    |   NEWLINE
    ;

expr returns [int value]
    :   e=multExpr {$value = $e.value;}
        (   '+' e=multExpr {$value += $e.value;}
        |   '-' e=multExpr {$value -= $e.value;}
        )*
```

Break on: All Location Consume LT Exception   Break on Terminate

Output
14

Parse Tree
root
prog
stat
expr
multExpr + multExpr
atom atom * atom
2 3 4

Stack
Rule

Zoom

Input Output Parse Tree AST Stack Events

Syntax Diagram Interpreter Debugger Console

9 rules 15:15 Writable

Was haben wir gelernt?

- Parsergeneratoren gehören heute zum Werkzeugsatz jeden Softwareingenieurs
- Neben Cocktail gibt es freie Initiativen, z.B. ANTLR
- Leider erfasst der Parser nur die kontextfeie Struktur des Programms oder Dokuments; Kontextbedingungen und Integritätsbedingungen bleiben der *statischen semantischen Analyse* vorbehalten.

The End